下载APP

15｜汇编语言学习（二）：熟悉X86汇编代码

2021-09-10 宫文学

《手把手带你写一门编程语言》 课程介绍 >

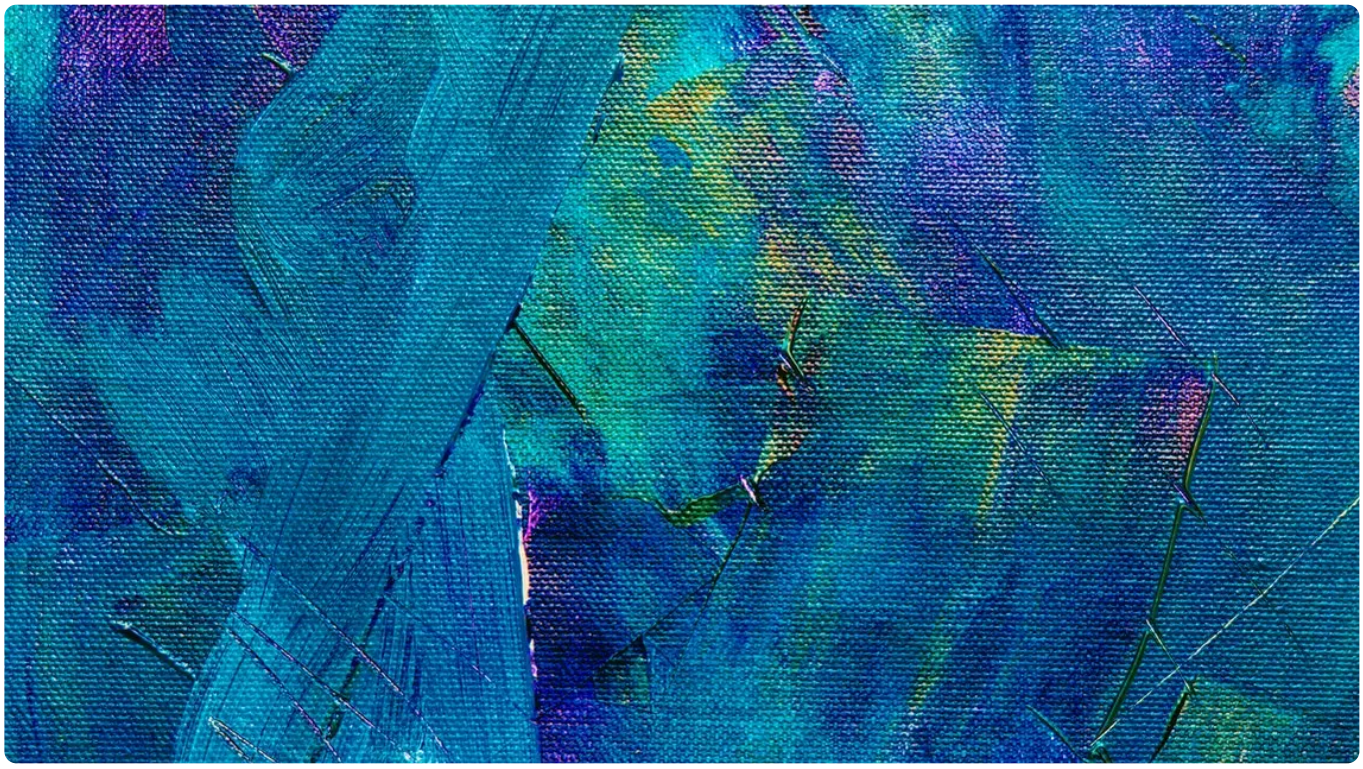

讲述：宫文学

时长 19:58 大小 18.29M

你好，我是宫文学。

上一节课，在开始写汇编代码之前，我先带着你在 CPU 架构方面做了一些基础的铺垫工作。我希望能让你有个正确的认知：**其实汇编语言的语法等层面的知识是很容易掌握的。**但要真正学懂汇编语言，关键还是要深入了解 CPU 架构。

今天这一节课，我们会再进一步，特别针对 X86 汇编代码来近距离分析一下。我会带你吃透一个汇编程序的例子，在这个过程中，你会获得关于汇编程序构成、指令构成、内存访问方式、栈帧维护，以及汇编代码优化等方面的知识点。掌握这些知识点之后，我们后续生成汇编代码的工作就会顺畅很多了！

好了，我们开始第一步，通过实际的示例程序，看看 X86 的汇编代码是什么样子的。

学习编译器生成的汇编代码

按我个人的经验来说，**学习汇编最快的方法，就是让别的编译器生成汇编代码给我们看。**

比如，你可以用 C 语言写出表达式计算、函数调用、条件分支等不同的逻辑，然后让 C 语言的编译器编译一下，就知道这些逻辑对应的汇编代码是什么样子了，而且你还可以分析每条代码的作用。这样看多了、分析多了以后，你自然就会对汇编语言越来越熟悉，也敢自己上手写了。

我们还是采用上一节课那个用 C 语言写的示例函数 foo，我们让这个函数接受一个整型的参数，把它加上 10 以后返回：

复制代码

```
int foo(int a){
    return a+10;
}
```

接着，再输入下面的 clang 或 gcc 命令：

复制代码

```
clang -S foo.c -o foo.s
或
gcc -S foo.c -o foo.s
```

然后我们用一个文本编辑器打开 foo.s，你就会看到下面这些汇编代码：

复制代码

```
    .section    __TEXT,__text,regular,pure_instructions
    .build_version macos, 11, 0 sdk_version 11, 3
    .globl  _foo                            ## -- Begin function foo
    .p2align    4, 0x90
_foo:                                   ## @foo
    .cfi_startproc
## %bb.0:
    pushq   %rbp
    .cfi_def_cfa_offset 16
    .cfi_offset %rbp, -16
    movq    %rsp, %rbp
    .cfi_def_cfa_register %rbp
```

```
13      movl    %edi, -4(%rbp)
14      movl    -4(%rbp), %eax
15      addl    $10, %eax
16      popq    %rbp
17      retq
18      .cfi_endproc
19                                          ## -- End function
20  .subsections_via_symbols
```

你第一次看到这样的代码的时候，可能会有点被吓着。这都是些什么呀！

不要怕，我给你梳理和解释一番，你就能慢慢适应这种代码形式，并且能看出其中的门道了。我做了一张图，几乎把这里面的每一行都做了解释，你先看一下:

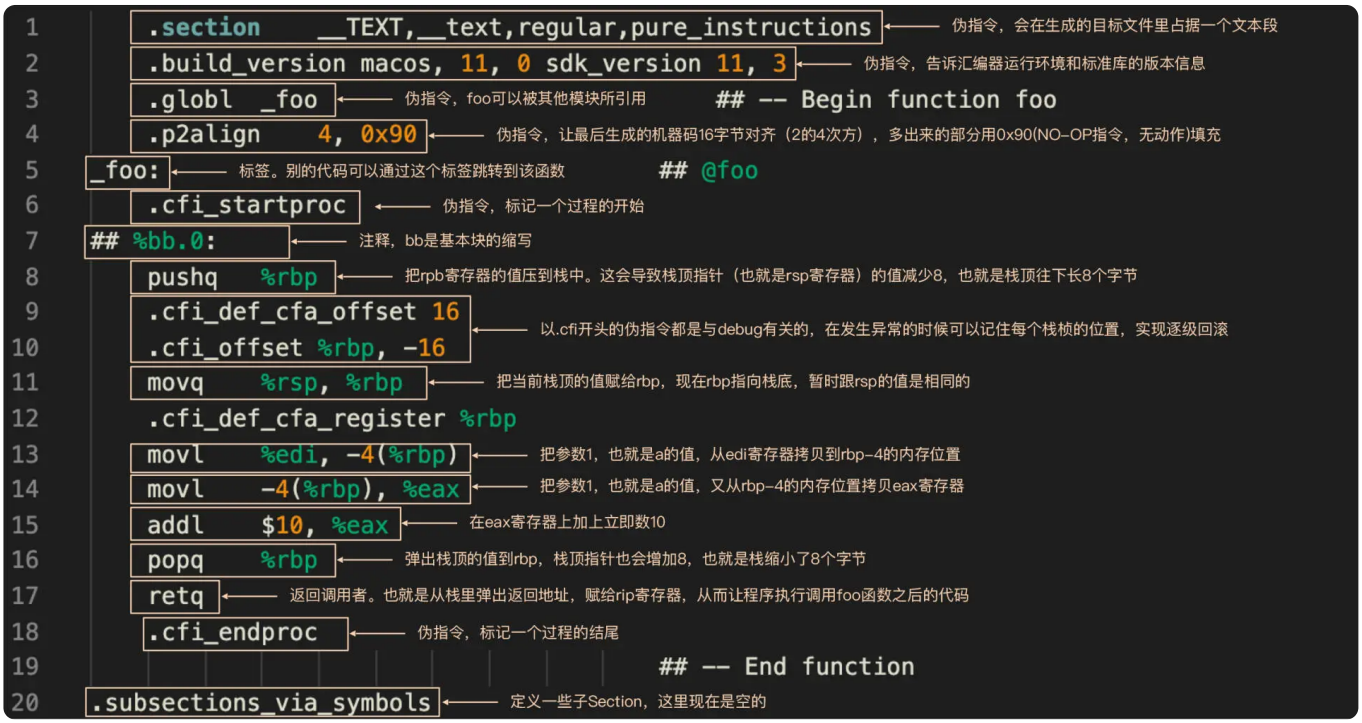
.section __TEXT,__text,regular,pure_instructions ← 伪指令，会在生成的目标文件里占据一个文本段
.build_version macos, 11, 0 sdk_version 11, 3 ← 伪指令，告诉汇编器运行环境和标准库的版本信息
.globl _foo ← 伪指令，foo可以被其他模块所引用
-- Begin function foo
.p2align 4, 0x90 ← 伪指令，让最后生成的机器码16字节对齐（2的4次方），多出来的部分用0x90(NO-OP指令，无动作)填充
_foo: ← 标签。别的代码可以通过这个标签跳转到该函数
@foo
.cfi_startproc ← 伪指令，标记一个过程的开始
%bb.0: ← 注释，bb是基本块的缩写
pushq %rbp ← 把rpb寄存器的值压到栈中。这会导致栈顶指针（也就是rsp寄存器）的值减少8，也就是栈顶往下长8个字节
.cfi_def_cfa_offset 16
.cfi_offset %rbp, -16 ← 以.cfi开头的伪指令都是与debug有关的，在发生异常的时候可以记住每个栈桢的位置，实现逐级回滚
movq %rsp, %rbp ← 把当前栈顶的值赋给rbp，现在rbp指向栈底，暂时跟rsp的值是相同的
.cfi_def_cfa_register %rbp
movl %edi, -4(%rbp) ← 把参数1，也就是a的值，从edi寄存器拷贝到rbp-4的内存位置
movl -4(%rbp), %eax ← 把参数1，也就是a的值，又从rbp-4的内存位置拷贝eax寄存器
addl $10, %eax ← 在eax寄存器上加上立即数10
popq %rbp ← 弹出栈顶的值到rbp，栈顶指针也会增加8，也就是栈缩小了8个字节
retq ← 返回调用者。也就是从栈里弹出返回地址，赋给rip寄存器，从而让程序执行调用foo函数之后的代码
.cfi_endproc ← 伪指令，标记一个过程的结尾
-- End function
.subsections_via_symbols ← 定义一些子Section，这里现在是空的

首先我要说明一下，这个汇编文件采用的是 GNU 汇编器的语法。可能你之前学的是其他汇编器，语法可能会不同，不过看一阵子也就会习惯了。如果你在使用中遇到什么问题，也可以随时查阅GNU 汇编器的手册。

GNU 汇编器语法的特点是：

复制代码

```
1  助记符  源操作数，目的操作数
```

也就是说，比如在“addl　10,10 是源操作数，%eax 是目的操作数。整条指令的意思就是把立即数 10 加到 eax 寄存器原来的值上，并把结果保存在 eax 寄存器。

好，我们现在回到图中这个汇编代码里来，你先看看这个汇编代码的头几行。你会注意到，头几行都是以“.”号开头的。这些以“.”号开头的指令，叫做**伪指令**，或者叫做 directive。它是写给汇编器看的，不是翻译成机器码的指令，这些伪指令会帮助汇编器生成正确的目标文件。

比如，第一句用了一个.section 伪指令。汇编器生成的目标文件中，会有 1 到多个 section，或者叫做**段**。每个段里面放不同的内容，有的是放代码的，有的是放数据的。

目标文件中的这些段，会被链接程序合并、组装到一起，形成可执行文件。当可执行文件加载到内存的时候，就会形成我们在第 12 节课里讲到的那种内存布局，分为文本段、初始化后的数据段、未初始化的数据段等。这一切的源头，就是在汇编代码中定义的 section，以及子 section。当前我们定义的 section，是一个文本段，里面放的是纯代码。

接下来，.build_version 提供了目标代码的运行环境和标准库的版本。对于 macOS 和 Linux 来说，它们的二进制目标文件的格式是不同的。

.globl _foo 的意思，是 _foo 标签可以被外部模块所链接。也就是说，如果另一个模块里引用了 foo 函数，那么它可以跳转到 _foo 标签所指示的代码地址来。

.p2align 的意思是，对于该 section 生成的二进制程序片段，必要时汇编器要在尾部添加一些填充性的内容，让它总的字节数能够被 16 整除。

这是什么意思呢？这涉及到 CPU 在内存中读取数据的性能问题。通常，如果数据是内存对齐的，读取数据的性能更高。甚至有些指令，特别是向量计算的指令，要求读取的数据必须是内存对齐的。在这里，我们是把生成的机器码做内存对齐，这样 CPU 读取机器码的性能会更高。内存对齐是在汇编代码中常见的一个现象，我这里先简单介绍一下，后面你在设计栈桢的时候还会再次遇到。

除了这几个伪指令之外，还有几个以.cfi 开头的。这些伪指令都是为了生成与 debug 有关的信息。如果你去掉它们，也不会影响剩下的汇编代码编译成正常的可执行文件。

实际上，这个文件里大部分伪指令都可以去掉，都不影响最后的编译和链接。你看一下下面这个示例代码，这里面我去掉了大部分令人眼花缭乱的伪指令，看上去清爽多了。

复制代码

```
#foo_x86_pure.s    去掉了大部分伪指令的汇编代码
.globl  _foo                                    ## -- Begin function foo
_foo:                                           ## @foo
    pushq   %rbp
    movq    %rsp, %rbp
    movl    %edi, -4(%rbp)
    movl    -4(%rbp), %eax
    addl    $10, %eax
    popq    %rbp
    retq
```

其中，我保留了.globl _foo，因为我想在另一个程序中调用 foo 函数。这个调用者的代码如下：

复制代码

```
//callfoo.c   调用采用汇编代码编写的foo函数，并打印出计算结果。
#include "stdio.h"

int foo(int a);

int main(){
    printf("foo(2) = %d\n", foo(2));
}
```

接着，我再执行下面两行命令，就会生成一个叫做 callfoo 的可执行文件。

复制代码

```
as foo_x86_pure.s -o foo_x86_pure.o
clang callfoo.c foo_x86_pure.o -o callfoo
```

```
➜  13 git:(master) ✗ as foo_x86_pure.s -o foo_x86_pure.o
➜  13 git:(master) ✗ clang callfoo.c foo_x86_pure.o -o callfoo
➜  13 git:(master) ✗ ./callfoo
foo(2) = 12
```

这里面，第二句的 clang 命令暗中做了两件事情。首先是把 callfoo.c 编译成目标文件，然后用 ld 工具把两个目标文件链接成了一个可执行文件。

通过上面的练习，一方面你能了解一个多模块的程序是如何链接到一起的，另一方面呢，你也可以放开手脚，大胆地写纯汇编代码，不用担心不了解那么多伪指令了。

好了，我们再回到纯净版本的汇编代码中，看看这些代码都做了些什么事情，这样你会慢慢对汇编代码熟悉起来。

理解汇编代码的语法和功能

为了让你更清晰地阅读，我给代码也都加上了注释。

复制代码

```
.globl  _foo            #伪指令，让foo可以被其他模块所引用
_foo:                   #标签。别的代码可以通过这个标签跳转到该函数。
    #序曲（prologue）
    pushq   %rbp        #把rpb寄存器的值压到栈中。这会导致栈顶指针（也就是rsp寄存器）的值
    movq    %rsp, %rbp  #把当前栈顶的值赋给rbp，现在rbp指向栈底，暂时跟rsp的值是相同的。

    #函数体
    movl    %edi, -4(%rbp) #把参数1，也就是a的值，从edi寄存器拷贝到rbp-4的内存位置。
    movl    -4(%rbp), %eax #把参数1，也就是a的值，又从rbp-4的内存位置拷贝eax寄存器。
    addl    $10, %eax      #在eax寄存器上加上立即数10

    #尾声（epilogue）
    popq    %rbp        #弹出栈顶的值到rbp，栈顶指针也会增加8，也就是栈缩小了8个字节。
    retq                #返回调用者。也就是从栈里弹出返回地址，赋给rip寄存器，从而让程序执
```

在这段代码中，“_foo:”是一个标签，可以作为代码跳转的目的地。在这里你就知道了，**汇编语言里是没有函数的概念的，函数也不过意味着一段代码的开始地址而已。**在后面，我们也会为 if 语句和 for 语句等生成跳转指令，跳转指令的目的地也是一个标签，本质上跟函数入口的这个标签没啥区别。

foo 函数对应的所有汇编代码，被我划分成了序曲、函数体和尾声三个部分。序曲和尾声两个部分，都是用来维护栈桢的。

在这里，我想借着这段代码，再带你了解一下与栈桢有关的知识点。我画了几个图，依次给你展示了栈和寄存器里的数据随着代码执行不断变化的情况。

我们先来看第一、二步的示意图：

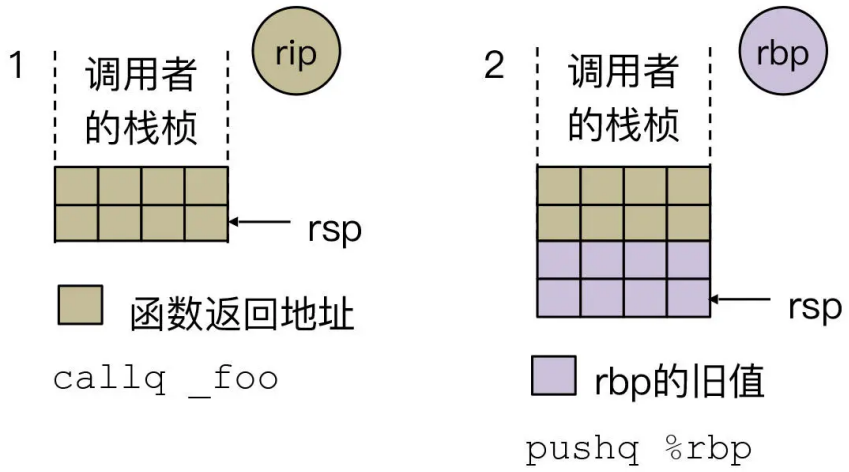

极客时间

第一步是调用者执行 callq _foo 指令。

这个时候，callq 指令会把 rip 寄存器的值压入到栈中。rip 的值是当前指令的下一条指令，也就是 callq 之后的指令。把这个值压入到栈里以后，栈顶指针的值会减 8，指向心的栈顶。那这里为什么会是减法呢？这个原因我们已经在第 12 节说过了，栈是从高地址向低地址延伸的。

第二步，执行 pushq %rbp。

这条指令是把 rbp 寄存器的值压到栈里。rbp 是一个 64 位的寄存器，所以要占用 8 个字节。push 指令还会移动栈顶指针，让 rsp 的值减 8。

然后我们再来看第三、四步的执行结果：

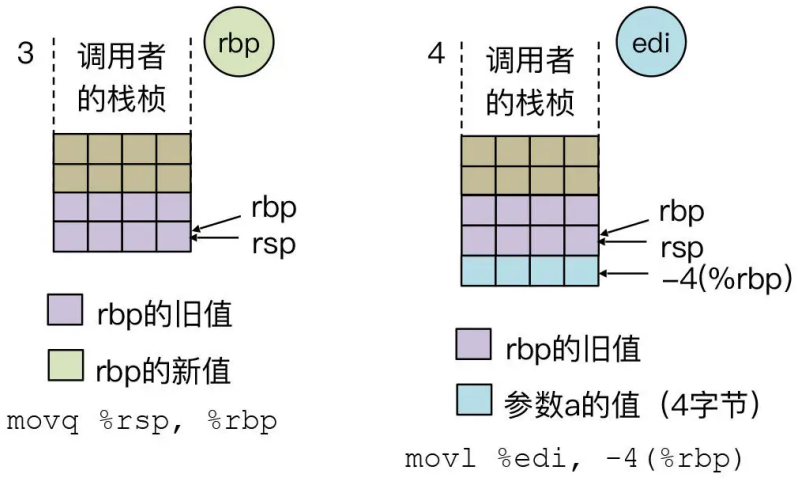

极客时间

第三步，执行 movq %rsp %rbp。

这条指令会把 rsp 的值拷贝到 rbp，所以 rbp 寄存器现在拥有了一个新值，跟 rsp 一起，都指向了新的栈顶。如果我们后面扩展栈桢，那么 rsp 的值会继续减少，保持指向栈顶，而 rbp 会一直指向这里，也就是栈桢的底部。

第四步，执行 movl %edi, -4(%rbp)。

这是把 edi 寄存器的值保存到栈底向下的 4 个字节中。因为这是一个 32 位整数，所以只需要占据 4 个字节。

注意，这里 edi 的值，就是 foo 函数第一个参数的值，也就是参数 a。根据 c 语言的调用约定，前 6 个参数都是通过寄存器来传递的，这样性能更高。超过 6 个的之后的参数呢，还是要通过栈桢传递。

这行代码里还有一个操作数是 -4(%rbp)。这是一个内存地址，它的具体值是 rbp 寄存器的值减去 4，这就涉及到 X86 架构下内存的寻址方式这个知识点。

在 X86 下访问内存，有**直接内存访问**和**间接内存访问**两种方式。直接内存访问指的是在指令后面直接跟内存的地址，比如“mov 地址值, %eax”的意思，就是把某地址的内容拷贝

到寄存器。在跳转和函数调用等指令中，我们通常是用标签来代替实际的内存地址，因为标签在链接的时候就会被计算成内存地址。

而间接内存访问，是基于寄存器的值去计算内存地址。间接内存访问的完整格式是：

偏移量（基址，索引值，字节数）

计算出来的内存地址是：基址 + 索引值 * 字节数 + 偏移量

我这里举例说一下：

8(%rbp)，是比 %rbp 寄存器的值加 8。

-8(%rbp)，是比 %rbp 寄存器的值减 8。

（%rbp, %eax, 4）的值，等于 %rbp + %eax*4。这个地址格式相当于访问 C 语言中的数组中的元素，数组元素是 32 位的整数，它的索引值是 %eax，而数组的起始位置是 %rbp。其中字节数只能取 1、2、4、8 这四个值。这种寻址方式为数组或矢量数据的访问提供二楼便利。

好了，内存寻址方式我们就了解到这里。对于每种 CPU 架构，支持的寻址方式都是不太相同的，你在接触一个新的架构时需要关注一下这个点。

现在回到正题，来看第五、六条的指令：

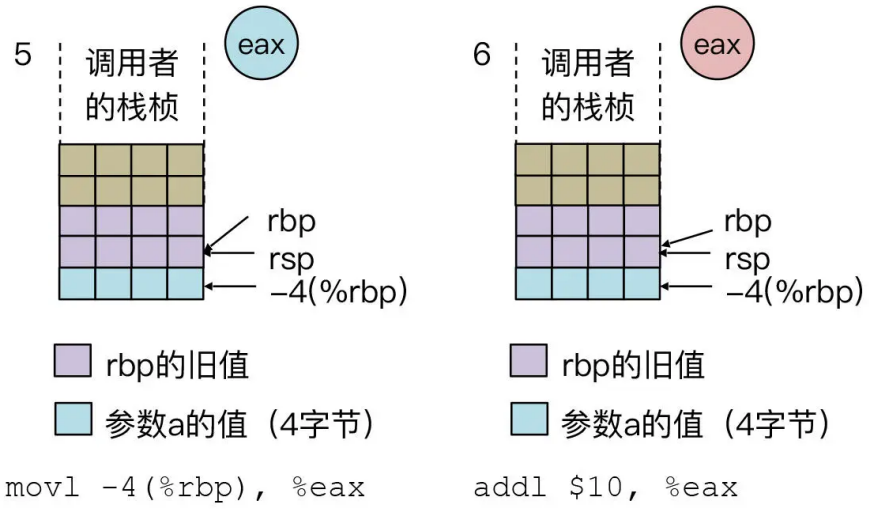


```
movl -4(%rbp), %eax
```

```
addl $10, %eax
```

极客时间

第五步，执行 movl -4(%rbp), %eax。

这个语句现在你自己也能看懂了。它是把刚才那个地址中的值，拷贝到 eax 寄存器中。

第六步，addl $10, %eax。

这条语句的意思是在 eax 寄存器上加上立即数 10。在 X86 的汇编代码中，立即数是以 $ 开头的。

最后我们来看下最后两步的执行结果：

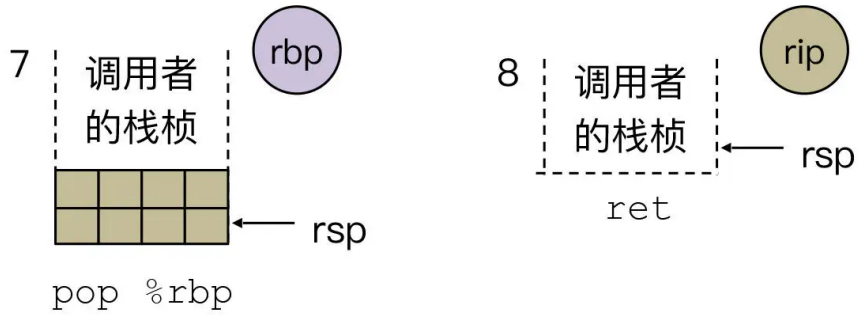

极客时间

第七步，popq %rbp。

这里是说弹出栈顶的值到 rbp，栈顶指针也会增加 8，也就是栈缩小了 8 个字节。

最后一步，执行 ret 指令。

这个指令会从栈里弹出返回地址，设置到 rip 中去。同时，栈顶指针 rsp 的值也加了 8，栈进一步缩小。执行完 ret 指令以后，CPU 就会去执行 rip 指向的代码，也就是调用者的代码中 callq _foo 之后的代码。

那返回值在哪里呢？根据调用约定，foo 函数的调用者是就是从 eax 寄存器中取返回值的。

刚才这 8 个步骤，就是 foo 函数从被调用到返回的全过程。多分析几次这样的汇编代码，你就能对栈的变化过程，以及各个寄存器的值的变化过程有一个直观的认知，这样就能从最底层理解程序运行的过程了。

不过，我们的分析还没有停止。我们继续打量一下上面的汇编代码，你可能还会产生几个问题。通过解决这些问题，你可以更深入地了解 X86 汇编代码，并初步学习到对汇编代码进行优化的技术。

汇编代码的优化

问题 1：在第 4 步，执行 movl %edi, -4(%rbp)，也就是把 edi 的值保存到内存的时候，你会发现目标地址其实是在栈顶外面的，超越了 rsp 指向的位置。这是怎么回事呢？难道我们的程序还可以访问栈之外的内存吗？

确实如此，这其实是一个 ABI 的规定。System V ABI 中针对 amd64 架构规定，程序可以访问栈顶之外 128 个字节的内存空间，这 128 个字节足够保存 16 个长整型数据，或者 32 个整型数据，还是挺大的。这样有什么好处呢？这可以减少我们的指令数量。否则，我们就要为 foo 函数新增加两条指令，用来移动栈顶指针了。

再来说说问题 2：我们之前讲过栈顶指针，也就是 rsp。怎么这个程序里还有一个指针 rbp 呀？它有什么用？

答案是，你不一定非要用它，这是个历史遗留的习惯。这个指针的作用，是在退出函数的时候，可以一步回到前一个栈桢，或者通过 rbp 的值来访问超过 6 个之外的参数（保存在调用者的栈桢里）。但你通过 rsp 值的加和减、以及成对的 push 和 pop 指令，其实也可以保证正确回到前一个栈桢。

所以，在新的架构下，其实我们不用这个指针也是可以的。这样的话，也就没有必要为了使用 rbp 而把它原来的值保存到内存里，这样也就能减少了两次内存读写操作，提升系统的性能。

然后是问题 3：你可能会说，我怎么觉得这个程序里的很多代码都在做无用功呀。特别是，先把 edi 寄存器的值保存到内存中，然后又从内存拷贝到 eax 寄存器，在 eax 上做计算。为什么不直接从 edi 拷贝到 eax 呢？这样就不需要做内存读写了呀？

确实如此。因为我们当前生成的汇编代码是没有做优化的。而寄存器机最重要的优化，就是尽量多使用寄存器，减少内存读写。我们后面还会介绍寄存器分配的思路和算法。不过，我们现在就可以先手工优化一下这段汇编代码，把刚才的问题 2 和问题 3 涉及的内容都优化一下：

复制代码

```
1 ##foo_x86_opt2.s
2 .globl  _foo            #伪指令，让foo可以被其他模块所引用
3 _foo:                   #标签。别的代码可以通过这个标签跳转到该函数。
```

```
4       #函数体
5       movl    %edi, %eax      #把参数1，也就是a的值，从edi寄存器拷贝到eax。
6       addl    $10, %eax       #在eax寄存器上加上立即数10
7
8       #尾声（epilogue）
9       retq                    #返回调用者。也就是从栈里弹出返回地址，赋给rip寄存器，从而让程序执
```

修改完毕以后，你会发现，foo 函数从 7 条指令减少到了 3 条，并且减少了 4 次内存读写。既缩小了代码尺寸，又提高了性能，这就是我们这次代码优化起到的作用。

那这已经优化到了最佳状态了吗？其实还没有，还是有优化空间的。请看下面的代码：

复制代码

```
1  ##foo_x86_opt2.s
2  .globl  _foo            #伪指令，让foo可以被其他模块所引用
3  _foo:                   #标签。别的代码可以通过这个标签跳转到该函数。
4       #函数体
5       leal    10(%rdi), %eax   #把参数1加上10，然后拷贝到eax。
6
7       #尾声（epilogue）
8       retq                    #返回调用者。也就是从栈里弹出返回地址，赋给rip寄存器，从而让程序执
```

这里呢，我把用一条 lea 指令代替了原来函数体中的两条指令。指令数量又减少了一条，并且 foo 函数整体所花费的时钟周期也减少了。你可以在编译命令中加上 -O1 或 -O2 参数，也会获得类似的代码。

我这里再给你介绍一下 **lea 指令**，这个指令原本是用于做地址计算的。lea 是“load effective address”的缩写，装载有效地址。它的源操作数是一个间接寻址模式的地址，在计算出地址值之后赋值给目的操作数。

在这里，我们是利用了 lea 指令在一条指令里能够同时完成计算和给寄存器赋值的能力，把它用于数学运算了。这就相当于上一节课我们接触到的 ARM 架构的 add 指令，那个 add 指令能接受两个源和 1 个目的，也能够同时完成加法运算和给寄存器赋值。

这种同样的功能可以用不同的指令实现，并且选择最优的指令组合的机制，叫做**指令选择**。这也是一种代码优化技术。

课程小结

好了，这就是今天课程的全部内容了。我们这节课近距离观察和分析了 X86 汇编的代码，我希望你记住这几个知识点：

GNU 汇编器支持的 X86 汇编由伪指令、指令和标签构成。伪指令是写给汇编器的，你在学习的过程中可以暂时忽略大部分的伪指令。指令能够生成最后的机器码，标签会被链接器转化成内存地址，用于支持函数调用、跳转等功能。

X86 的指令由助记符、源操作数和目的操作数构成。不过，有的指令没有目的操作数（如 pushq %rbp），还有的指令只有助记符（如 retq）。操作数可以是立即数、寄存器或内存地址。内存地址包括直接内存访问和间接内存访问两种方式。

在运行一个函数时，会涉及到与栈的使用有关的代码。我们用 rsp 寄存器指向栈顶。push、pop、call 和 ret 指令，都会导致 rsp 指针移动。在后面的课程里，你还可以手工修改 rsp 的值，从而改变栈的大小。

最后，我们还有多种技术可以对汇编代码进行优化。首先是寄存器分配算法，可以让程序尽量少访问内存，多利用寄存器进行计算，我们后面的课程里也会围绕这个算法展开比较多的讨论。另外，指令选择算法也会挑选出更优的指令组合，让代码的性能更高。

今天这节课，我们已经初步熟悉了 X86 汇编代码。那么下节课，我们就动手用编译器生成这样的汇编代码吧！在这个过程中，你还会学习到更多关于 X86 汇编代码的知识。

思考题

我们这节课是以整数运算为例来讲解的。如果把整数换成长整数，也就是 foo 函数的参数和返回值都改成长整型，对应的汇编代码会有什么不同呢？我建议你尝试一下，然后把你的发现在留言区分享出来。

感谢你和我一起学习，也欢迎你把这节课分享给更多对汇编代码感兴趣的朋友。我是宫文学，我们下节课见。

资源链接

这里我放了一个 GNU 汇编器的手册。

分享给需要的人，Ta订阅后你可得 20 元现金奖励

赞 0 提建议

© 版权归极客邦科技所有，未经许可不得传播售卖。 页面已增加防盗追踪，如有侵权极客邦将依法追究其法律责任。

上一篇 14 | 汇编代码学习（一）：熟悉CPU架构和指令集

下一篇 16 | 生成本地代码第1关：先把基础搭好

精选留言 (5)

写留言

有学识的兔子
2021-09-19

在gcc 7.2.0下，long foo(long a) 翻译成汇编与之前int foo(int a)基本上是一样的，按理说参数a的偏移量是8，但实际还是4。是不是long型在这个编译器下等同于int型？

奋斗的蜗牛
2021-09-11

汇编难学，因为很多指令数据传递都是隐式的规则，没有高级语言清晰

pedro
2021-09-10

很用心，每一步都有图

展开

quanee
2021-09-10

老师, 后面课程会实现汇编器吗?

展开

罗乾林
2021-09-10

数据长度由4字节变8字节，汇编指令的l后缀变为q，寄存器变为64位寄存器 ，偏移量由-4变为-8

.cfi_startproc
 pushq %rbp...

展开